

7D-03

## 模倣学習型ニューラルネットワークを活用した歩行流制御施策の最適化

田中 福治<sup>\*1</sup> 天野 辰哉<sup>\*1</sup> 内山 彰<sup>\*1</sup> 廣森 聡仁<sup>\*1</sup> 山口 弘純<sup>\*1</sup> 中村 佑輔<sup>\*2</sup><sup>\*1</sup> 大阪大学 大学院情報科学研究科 <sup>\*2</sup> 株式会社 NTT ドコモ, クロステック開発部

{f-tanaka, t-amano, uchiyama, hiromori, h-yamagu}@ist.osaka-u.ac.jp yuusuke.nakamura.xf@nttdocomo.com

## 1 はじめに

群衆が密集する場所では、過密に起因する転倒事故、緊急時避難の阻害、テロや犯罪の危険性など、人々の安全が脅かされる可能性が高まる。また、大規模イベントなどによる群衆混雑は、周辺地域の交通渋滞を引き起こし、旅客飽和など公共交通などのインフラを麻痺させることも多い。したがって、群衆誘導や監視、警備や通行計画策定による混雑緩和や平滑化などの適切な対策を実施することが求められる。ここで、分散退場やインセンティブを与えて迂回させ、交通機関への到着時間をずらすなどの行動変容による人の流れの制御が注目を集めている。

しかし、施策の有効性を予測することは難しく、実地試験による評価には多量のコストが必要となってしまう。そこでマルチエージェントシミュレーションを利用することを考えるも、施策の探索空間が広いことや、大規模な群衆シミュレーションに多大な実行時間がかかることから、グリッド探索、遺伝的アルゴリズム、ベイズ最適化などの従来の手法 [1] では、最適な施策の探索に膨大な時間を要してしまう。実際の退場時刻が近づくにつれて、利用できる情報の正確性が向上することからも、施策を求めるのにかかる時間は小さいことが望ましい。

そこで本論文では、ニューラルネットワークによるマルチエージェントシミュレータの代理モデルを活用した、勾配ベースのブラックボックス最適化手法を提案する。提案手法ではシミュレータとその評価関数をニューラルネットワークにより微分可能な関数として複製し、その勾配情報に基づいて施策を最適化することで、最適な施策の特定に要する時間を短縮する。

## 2 問題設定

本研究では、すべての人の経路の起点はイベント会場であり、バス停や駅などの目的地のいずれかに向かうと仮定する。また、イベント管理者は、参加者全員が同時に目的地（駅など）に殺到しないように、立ち寄らせたい場所（商業施設）と滞在時間の設定に相当する施策を見つけたいと仮定する。立ち寄らせたり滞在させたりする行動変容は、金銭的なクーポンなどのインセンティブによって行われる。

具体的には、施策は立ち寄らせたい場所ごとに定義された2つのパラメータで構成される。この2つのパラメータは、各場所がどの程度強く人々を惹きつけ、どの程度長く滞在させるかを示す。施策を決定すると、マルチエージェントシミュレータに実装された報酬反応モデル、経路選択モデル、その他のモデルに従い、人々がどのように移動するかをシミュレートすることができる。これにより、イベント管理者は、混雑度、最終目的地に到達するまでのエージェントの移動時間、エージェントをポリシーに適合するように制御するための金銭的成本を観測することがで

きる。

本研究で想定している道路ネットワーク  $G$  は、ノード集合  $N$  とエッジ集合  $E \subseteq N \times N$  で表される。エッジは道路を表し、ノードは会場や駅、商業施設、交差点などのスポットを表す。ここでノード集合は、会場のように出発地点となる始点ノード  $S$ 、商業施設などの施策の対象となるような迂回ノードの集合  $E$ 、駅などの目的地となうような終点ノードの集合  $D$ 、その他の交差点のような中継ノード  $I$  の4種類のノードから構成される。これらのノード集合には共通の要素はなく、ノードの全体集合  $N$  は、これら4つの集合の和集合として定義する。

道路ネットワークと会場から出発する人数、目的地を表すシナリオが与えられたとき、我々の目的は混雑度、施策の金銭的成本、移動時間の合計を最小化する施策を見つけることである。目的関数  $\mathcal{F}$  は、渋滞のペナルティ  $\mathcal{P}$ 、施策コスト  $\mathcal{M}$ 、平均移動時間  $\mathcal{T}$  の線形結合として定義される：

$$\operatorname{argmin}_{\text{policy}} \mathcal{F} \quad (1)$$

$$\mathcal{F} = w_1 \mathcal{P} + w_2 \mathcal{M} + w_3 \mathcal{T} \quad (2)$$

以降では目的関数の値を人流評価値と呼ぶ。ここで、 $w_1, w_2, w_3$  は重みを表し、それぞれの因子のスケール調整を行うとともに、重要度を自由に変更可能としている。また、渋滞のペナルティ  $\mathcal{P}$  は駅の平均滞在人数に相当し、平均移動時間  $\mathcal{T}$  は退場を開始してから電車に乗るまでにかかる平均時間に相当する。さらに施策コスト  $\mathcal{M}$  は以下の式で定義される。

$$\mathcal{M} = \sum_{i \in E} (s_i + \alpha) g_i \quad (3)$$

ここで、 $\alpha$  は人を引き付けるために必要な最小インセンティブコスト、 $g_i$  は迂回ノード  $i$  の魅力を表す。また、人々に長期滞在を奨励すると一般的により多くの金銭的成本が発生するため、滞在時間パラメータ  $s_i$  も考慮する。

## 3 提案手法

施策評価や最適化のために、一般的にエージェントベースの歩行者シミュレーションが利用される。これらのシミュレーションは詳細な人の動きを表現できるが、計算コストが高く、実行に時間がかかるために、リアルタイムでの施策最適化に利用するのは現実的ではない。

そこで我々は施策を効率的かつ迅速に最適化することを目的として、ニューラルネットワークによるマルチエージェントシミュレータの代理モデルを活用した、勾配ベースのブラックボックス最適化手法を提案する。提案手法は主に2つのアプローチから構成される。一つ目はマルチエージェントシミュレーションで訓練されたニューラル

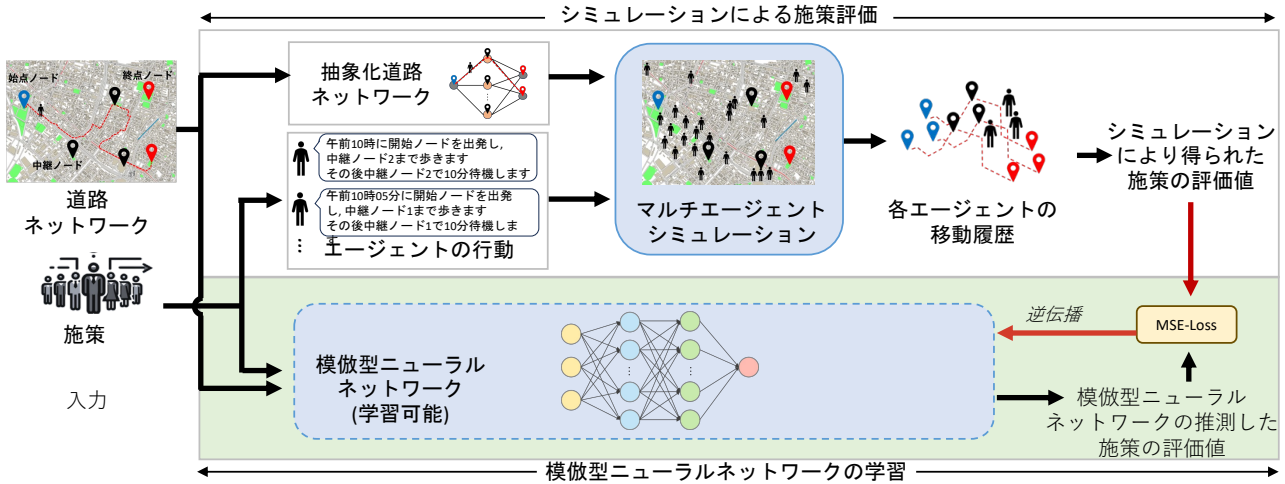


図1 模倣モデルの学習過程

ネットワークベースの模倣モデルを導入し、多様な施策の影響を迅速に推定することである。機械学習モデルは本質的に微分可能であるため、SGDやAdamなどの勾配ベースの最適化手法が適用可能である。そこで、人流評価値を推測する機械学習モデルを構築し、勾配降下法に基づいて人流評価値を最小化するように施策パラメータを繰り返し更新することで最適化を達成する。機械学習モデルとしては混雑度と平均移動時間の回帰タスクを同時に行う、マルチタスクのMLPを利用する。

二つ目は単純化された仮想道路網を導入し、現実の道路ネットワークの複雑さを低減し、学習を容易にすることである。この道路ネットワークは、「始点ノード」、「迂回ノード」、「終点ノード」の必須ノードと始点ノードと迂回ノード、迂回ノードと終点ノードのみを繋ぐエッジに構成要素を限定している。始点ノードは人の出発地点である会場、迂回ノードは周囲のレストランや商業施設などの迂回対象、終点ノードが最寄り駅に対応し、各エッジ長は各ノード間の最短経路に設定される。

#### 4 性能評価

本実験では提案手法の有効性の検証のために、5つのランダムな道路ネットワークにおける退場シナリオを用意し、実際にシミュレータを用いて施策の探索を行う手法との実行速度と精度の比較を行う。

本実験の人流シミュレーションにはSpace-Time Engineering社のScenargie<sup>®</sup>を用いる。用意したシナリオでは実際のイベントを参考として最寄り駅と会場、近くの商業施設をすべて含んだときの広さの2km×2kmのフィールドを用意し、このフィールド内に駅や商業施設、イベント会場をランダムに配置し、それらを必ず通過する道路ネットワークをランダムで生成している。ここで本実験では、限定された状況でも最適化を行うことができるのかを確認するために、会場は1つ、駅は2つ、施策対象の商業施設は3つに限定し、退場人数を20000人に固定している。

また、評価値の各要素の重みに関して、全ての重みを等分にすると、常に最適解が施策を打たないことになってしまったため、駅の混雑、平均移動時間、施策のコストの重

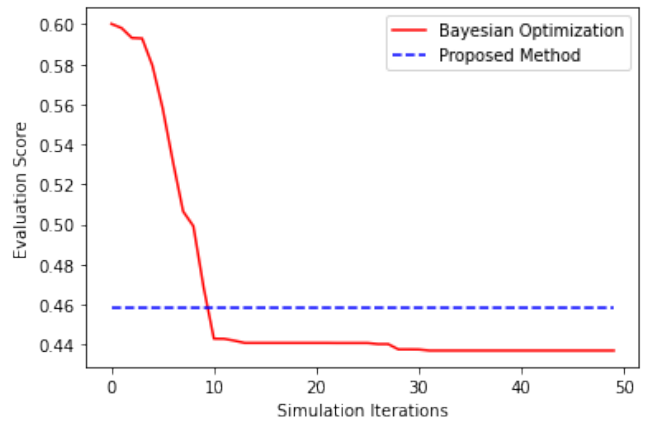


図2 シミュレータ実行回数毎の平均評価値

みを1:1:0.1としている。

実行回数毎の平均評価値を図2に示す。図2から、提案手法では平均して0.46、ベイズ最適化では平均して0.44の評価値を達成しており、提案手法がシミュレータを動かさずとも、シミュレータを動かして施策を探索した場合と同等の評価値を達成できていると言える。また図2から、提案手法と同じかそれよりも低い評価値を得られるまでにベイズ最適化では10回の平均シミュレーション実行回数が必要であることがわかる。シミュレーションを10回実行したときの平均所要時間が13,099秒で提案手法の所要時間が32秒であるため、探索時間を13,067秒削減できるといえる。

#### 参考文献

[1] Dong, Y., Jia, X., Yanagisawa, D. and Nishinari, K.: Optimising Pedestrian Flow Around Large Stadiums, *Collective Dynamics*, Vol. 6, pp. 1–18 (2021).